

Metodología Propuesta para Identificación del Huanglongbing (HLB) en Limón Persa Mediante una Red Neuronal Artificial

Galdino Martínez Flores¹

gmartinezf@itsm.edu.mx

<https://orcid.org/0000-0003-4981-8631>

Tecnológico Nacional de México Campus:
Instituto Tecnológico Superior de Misantla
México

Roberto Angel Meléndez Armenta

ramelendeza@itsm.edu.mx

<https://orcid.org/0000-0001-8994-0944>

Tecnológico Nacional de México Campus:
Instituto Tecnológico Superior de Misantla
México

Irahan Otoniel José Guzmán

iojoseg@itsm.edu.mx

<https://orcid.org/0000-0001-5336-0198>

Tecnológico Nacional de México Campus:
Instituto Tecnológico Superior de Misantla
México

RESUMEN

En esta investigación se propuso un modelo para identificar la enfermedad HLB en imágenes de hojas de limón persa mediante una red neuronal artificial (RNA). Se utilizaron imágenes de hojas de limón persa enfermas y no enfermas de HLB, éstas se convirtieron a escala de grises, se manipuló el brillo y se les asignó una resolución de 200 por 350 píxeles para cada una de ellas. Posteriormente se les aplicó el algoritmo de Canny para detectar bordes. Se utilizó la técnica de Análisis de Componentes principales (PCA) para reducir la dimensionalidad del tamaño de las imágenes, alcanzando una reducción del 50 por ciento para cada imagen. Para el proceso de clasificación se implementó una RNA y se empleó el algoritmo de validación cruzada para validar el modelo. Los resultados muestran que el modelo de red neuronal obtiene una exactitud máxima del 80% utilizando validación cruzada con 5 k-folds y tipo de aprendizaje supervisado. Por lo tanto, se recomienda el modelo con validación cruzada k folds para validar el modelo, debido a que alcanzó una mejor exactitud, además demuestra la utilidad de la aplicación de las herramientas de la Inteligencia artificial para la identificación de enfermedades en el sector agrícola.

Palabras clave: HLB; inteligencia artificial; red neuronal; validación cruzada; PCA.

¹ Autor principal.

Correspondencia: gmartinezf@itsm.edu.mx

Proposed Methodology for Huanglongbing (HLB) Identification in Persian Lemon Using an Artificial Neural Network (ANN)

ABSTRACT

In this research study, a model has been proposed to identify HLB disease in Persian lemon leaf images employing an Artificial Neural Network (ANN). The images of both HLB-infected and HLB-non-infected Persian lemon leaves were initially transformed to grayscale, brightness levels were adjusted, and each image was standardized to a resolution of 200 by 350 pixels. Then, the Canny algorithm was applied to detect edges in images. The Principal Component Analysis (PCA) technique was used to reduce the dimensionality of the images, resulting in a 50 percent reduction for each image. For the classification process, an ANN was implemented, and the cross-validation algorithm was applied to authenticate the model. The results revealed that the neural network model achieves a maximum accuracy rate of 80 percent through cross-validation with 5 k-folds and a supervised learning approach. Therefore, we recommend employing the k-fold cross-validation method to verify the model since it demonstrates superior accuracy. This outcome emphasizes the benefit of artificial intelligence tools within the agricultural sector for disease identification.

Keywords: *HLB; artificial intelligence; neural network; cross validation; PCA.*

Artículo recibido 22 agosto 2023

Aceptado para publicación: 24 setiembre 2023

INTRODUCCIÓN

El Huanglongbing (HLB), es la enfermedad más destructiva en la actualidad por la severidad de los efectos en producción, por la rapidez de dispersión, por afectar a todas las variantes de cítricos comerciales y por no tener cura aún (Wang et al., 2017). Cada árbol con HLB es eliminado para evitar la propagación de esta enfermedad. Esto puede causar la pérdida de gran parte de los cultivos sino se detecta y controla a tiempo, perdiendo paulatinamente la rentabilidad de los huertos (Zhang et al., 2014).

La severidad de esta enfermedad, causada por la bacteria *Candidatus Liberibacter* en sus tres variantes, ha preocupado a diversos entes vinculados a la producción de cítricos. Se han informado métodos de diagnóstico de laboratorio fiables para la identificación del HLB (Gao et al., 2013), incluida la microscopía electrónica, la cromatografía de capa fina (TLC) y la reacción en cadena de la polimerasa (PCR) (Zhang W, 2012).

En México, durante el primer año desde que el HLB fue detectado (2009) se estima que ha causado una reducción en el rendimiento de los árboles afectados de hasta un 50%, estimándose que en un plazo de cinco años, bajo un escenario de alto impacto de la enfermedad, las pérdidas potenciales de las zonas productoras serían de cerca de 3 millones de toneladas, equivalentes al 41% de la producción total del país (Trujillo-Arriaga, 2010).

La reducción y pérdida en la producción de cítricos afecta directamente al empleo, tanto en campo como en la agroindustria, y en empresas relacionadas a la producción, procesamiento y distribución de cítricos. Los expertos en identificación de síntomas del HLB, los observan en las hojas, los tallos y frutos de los árboles (FAO, 2014). Siendo las hojas donde se manifiestan en primer lugar, presentando las siguientes características: coloración amarilla pálida con áreas color verde, irregulares (moteado), manchas asimétricas, defoliación, engrosamiento y aclaración de las nervaduras, asimetría y difusión de colores en las nervaduras y folíolos, hojas pequeñas y rectas. Muchas veces puede confundirse con deficiencias de micronutrientes como: zinc, hierro, calcio, magnesio, manganeso y cobre (Alemán et al., 2007).

Las técnicas y métodos empleados para la identificación del HLB en diversas investigaciones se centran en técnicas moleculares, técnicas espectroscópicas y de imagen así como perfilado de

compuestos orgánicos volátiles de plantas para la detección de enfermedades.

En este sentido, Mishra et al. (2011) emplean un sensor óptico activo multibanda para la identificación de la enfermedad huanglongbing (HLB) en árboles de cítricos. Se realizan mediciones de la copa de los árboles. Este sensor se compone de cuatro iluminadores de banda estrecha con cuatro longitudes de onda multibanda diferentes; dos en la región visible y dos en la región infrarroja cercana. En este trabajo se utilizó la técnica de Análisis de Componentes Principales (PCA) para la eliminación de datos atípicos en las muestras. Para la clasificación de árboles infectados con HLB aplicaron técnicas de inteligencia artificial.

Por otra parte, Pourreza et al. (2014) desarrollaron una máquina de visión basada en sensores para la identificación del HLB a través de hojas sintomáticas bajo condiciones de campo controlado. Para ello, emplearon la combinación de una cámara en blanco y negro, con un sistema de iluminación de banda estrecha polarizada. En la clasificación utilizaron características simples basadas en histogramas estadísticos y aplicaron la técnica de clasificación Support Vector Machine (SVM) con una precisión mayor a 95%.

Deng X et al. (2014) emplearon un método basado en el análisis de componentes principales y Redes Neuronales Artificiales a partir de imágenes hiperespectrales para diagnosticar y clasificar el HLB de los cítricos con una precisión superior al 90%. Inclusive, se han adoptado métodos de formación de imágenes multiespectrales e hiperespectrales en el aire para la detección de HLB (Li X et al., 2011; Li X et al., 2012; Li H et al., 2014).

Kumar et al. (2010) evaluaron la información multiespectral en el aire e imágenes hiperespectrales para realizar la detección de HLB; obteniendo la precisión más alta de reconocimiento de aproximadamente el 86%. Sin embargo, resultó difícil distinguir los árboles infectados con HLB de otros árboles con deficiencia de nutrientes. El uso de la reflectancia de las copas de los árboles sanos y HLB en los rangos visibles e infrarrojo cercano fue capaz de detectar la mayoría de las áreas gravemente infectadas. Las precisiones de detección oscilaron entre el 43% y el 95%.

En esta investigación el objetivo es identificar la enfermedad conocida como huanglongbing en huertos de limón persa, basado en la identificación de los síntomas que se manifiestan en las hojas de los cítricos infectados con el HLB, a través de reconocimiento de patrones en imágenes, usando

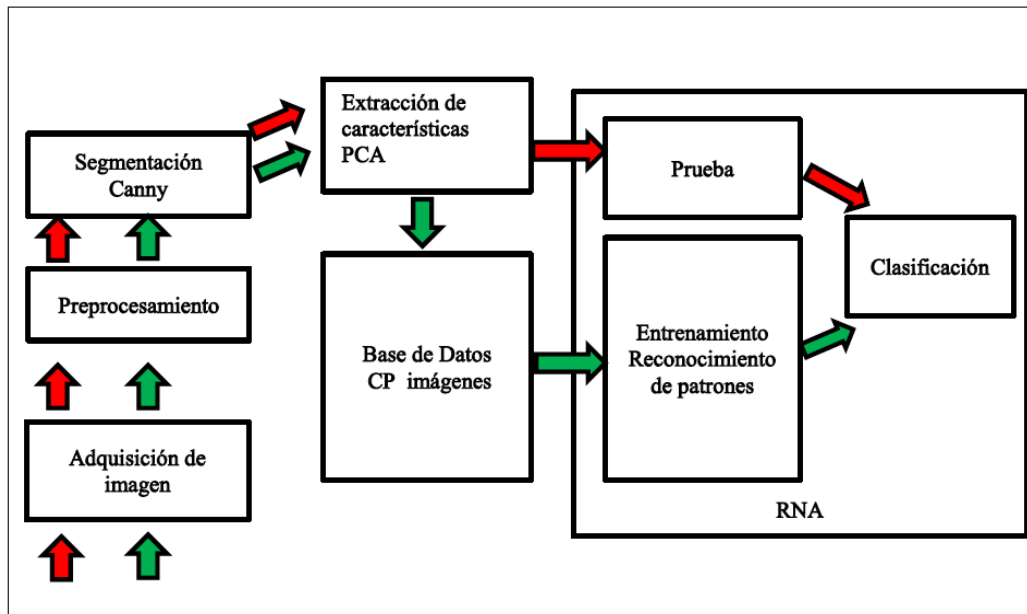
técnicas de inteligencia artificial para su análisis y clasificación.

METODOLOGÍA

En esta investigación, se buscó identificar la enfermedad huanglongbing en los árboles de limón persa, utilizando imágenes de hojas que presentan características sintomáticas a la enfermedad o descartar que este mal se encontrara presente. Para ello, en la figura 1 se muestra la metodología propuesta.

Figura 1

Metodología propuesta para la identificación del HLB en hojas sintomáticas de árboles de limón persa



Fuente: diseño propio a partir de la investigación realizada.

Adquisición de las imágenes


Las fotografías de hojas de limón persa con moteado asimétrico de HLB fueron proporcionadas por el comité estatal de sanidad vegetal del estado de Colima, mismas que fueron adquiridas en la campaña contra huanglongbing de los cítricos en ese estado. Las imágenes de hojas de limón persa sin la enfermedad del HLB fueron adquiridas en un huerto de la localidad de la espaldilla municipio de Misantla, Veracruz. En ambas situaciones se manejaron en un ambiente controlado. El tamaño de la muestra utilizada constó de 20 imágenes, de las cuáles, 10 estaban infectadas con HLB conteniendo síntomas característicos y las otras 10 correspondieron a hojas sanas.

Procesamiento de imágenes.

Las imágenes se convirtieron de color a escala de grises para percibir mejor los detalles de las hojas, el brillo y la resolución de 200 por 350 píxeles para estandarizarlas. El resultado de ambas operaciones se muestra en la figura 2 y figura 3.

Figura 2


Hojas de limón persa estandarizadas con resolución de 200 X 350 (a) Hoja a color con HLB (b) Hoja a color con HLB; (c) Hoja a color sin HLB y (d) Hoja a color sin HLB.



Fuente: Comité estatal de sanidad vegetal del estado de Colima e investigación propia realizada en campo.

Figura 3

Hojas de limón persa en escala de grises estandarizadas con resolución de 200 X 350. (a) Hoja en escala de grises con HLB. (b) Hoja en escala de grises con HLB. (c) Hoja en escala de grises sin HLB. (d) Hoja en escala de grises sin HLB.



Fuente: propia a partir de la investigación realizada.


Segmentación (detección de bordes)

La segmentación de imágenes divide la imagen en regiones u objetos de interés. Para realizarla se puede dividir la imagen basándose en cambios bruscos de nivel de gris (detección de puntos aislados, detección de líneas y, detección de bordes) o se puede dividir la imagen basándose en la búsqueda de zonas que tengan valores similares, conforme a unos criterios prefijados (crecimiento de región o umbralización) (González y Woods, 1996).

Se utilizó en esta fase el algoritmo de Canny para edtección de bordes. Este algoritmo está considerado como uno de los mejores métodos de detección de contornos mediante el empleo de máscaras de convolución y basado en la primera derivada. Canny (1986) propuso un método para la detección de bordes, este algoritmo consiste en los siguientes tres grandes pasos: obtención del gradiente: en este paso se calcula la magnitud y orientación del vector gradiente en cada píxel; supresión no máxima: en este paso se logra el adelgazamiento del ancho de los bordes obtenidos con el gradiente, hasta lograr bordes de un píxel de ancho e histéresis de umbral: en este paso se aplica una función de histéresis basada en dos umbrales; con este proceso se pretende reducir la posibilidad de aparición de contornos falsos. En la figura 4 y figura 5 se muestran los resultados obtenidos al aplicar este algoritmo.

Figura 4.

Hoja escala de grises con HLB.



Fuente: propia a partir de la investigación realizada.

Figura 5

Hoja con HLB y segmentada con el algoritmo de Canny.



Fuente: propia a partir de la investigación realizada.

Reducción de la dimensionalidad, mediante la técnica de análisis de componentes principales

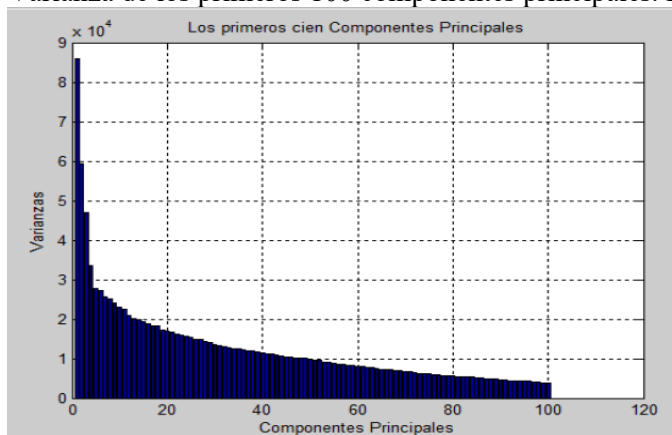
Una de las desventajas del tratamiento de imágenes, es la gran cantidad de información que utilizan para su almacenamiento, representación o manipulación en formato digital. Cada imagen en escala de grises se almacena en una matriz de m por n píxeles, donde m son las filas y n las

columnas de la matriz, cada posición de esta matriz almacena una intensidad de gris normalmente un valor entre 0 y 255, siendo 0 el gris más claro y 255 el gris más oscuro. Cada imagen se estandarizó a una resolución de 200 por 350 píxeles, debiendo almacenar 70000 datos, uno por cada píxel. Para reducir la dimensionalidad de las imágenes y por lo tanto el tamaño de cada imagen, se aplicó a cada una de ellas la técnica de Análisis de Componentes Principales (PCA). El análisis de componentes principales es una técnica de extracción de datos ampliamente utilizada en la actualidad. El objetivo principal que persigue dicha herramienta es reducir la dimensionalidad de un conjunto de observaciones con una gran cantidad de variables, ayudándose del estudio de la estructura de varianzas-covarianzas entre las variables que componen los datos de entrada. A partir de la proyección de los datos de entrada sobre las direcciones de máxima varianza se obtendrá un nuevo espacio de representación de los datos en el que se puede eliminar fácilmente aquellos componentes con menor varianza, garantizando la mínima pérdida de información (Sánchez, 2012).

Se generaron 350 componentes principales por cada imagen. Los cien primeros componentes cumplen con un alto porcentaje de variabilidad de los datos, la pérdida de información realmente es mínima, por lo que en esta investigación se toma la decisión de elegir los primeros cien componentes principales, esto debido a que representan noventa y tres por ciento de la variabilidad de los datos, tal como se manifiesta en la figura 6. Esto redujo el tamaño de cada imagen en un 50% de 70000 píxeles a 35000 componentes ($100 * 350$).

Figura 6.

Varianza de los primeros 100 componentes principales. Representan el 93% de la información.



Fuente: Diseño propio a partir de la Investigación realizada.

Diseño de la red neuronal multicapa backpropagation

Una red neuronal artificial es un método de la Inteligencia artificial para reconocer patrones en un conjunto de datos. Se conforman de una capa de entrada, capas intermedias y una capa de salida, cada capa tiene un número de neuronas determinado. Diversos autores afirman que no hay una arquitectura o configuración ideal para una red neuronal artificial, esta depende del tipo y cantidad de datos que van a procesar y que la configuración más eficiente se consigue a base de prueba y error, sin embargo, algunos también recomiendan que las capas ocultas se vayan reduciendo según el número de neuronas de la capa anterior entre dos.

Para clasificar se diseñó una red neuronal multicapa con una arquitectura de una capa de entrada, siete capas ocultas o intermedia y una capa de salida. La primera capa o capa de entrada está constituida por 35000 neuronas, que corresponden a los valores correspondientes a los componentes principales de cada hoja; la capa dos está formada 80 neuronas, la capa tres de 40, la capa cuatro de 20, la capa cinco de 10, la capa seis de 5 y la capa siete de una neurona correspondiente a la capa de salida, donde genera dos valores posibles, estos son cercanos a $\begin{bmatrix} 1 \\ 0 \end{bmatrix}$ ó $\begin{bmatrix} 0 \\ 1 \end{bmatrix}$; si el clasificador lo relaciona con la primera clase (hojas enfermas con HLB) genera la primera salida, en caso contrario, la salida se acerca a la segunda mostrada anteriormente, que corresponde a la clase de hojas sin la enfermedad HLB.

En el proceso de entrenamiento del modelo de aprendizaje automático se utilizó la técnica de validación cruzada. Berrar, Daniel. (2018) menciona que en la validación cruzada k-fold el conjunto de datos se divide en k subconjuntos disjuntos de datos de aproximadamente igual tamaño. El modelo se entrena usando k-1 subconjuntos, que, juntos, representan el conjunto de entrenamiento. Después, el modelo se aplica al subconjunto restante, que se denota como el conjunto de validación, y se mide el rendimiento. Este proceso se repite k veces con subconjunto de validación diferente cada vez. La precisión del modelo es un promedio de todas las precisiones de la validación cruzada. Se aplicó la validación cruzada k-fold a los veinte datos, diez de ellos pertenecientes a hojas enfermas y con síntomas característicos del HLB, los otros diez datos corresponden a hojas sin la enfermedad HLB. El conjunto de datos se debe dividir en grupos

(folds) iguales preferentemente.

Se dividió el conjunto de datos en 5 k-folds, cada uno de ellos de cuatro datos. El primer fold estuvo formado del dato uno al dato cuatro, el segundo del dato cinco al dato ocho; el tercero del dato nueve al dato doce; el cuarto del trece al dieciséis y el quinto del diecisiete al veinte.

Se realizaron cinco iteraciones debido a que son cinco k-folds. Dicho de otra forma, se entrena cinco veces con cuatro k-folds diferentes cada vez con su correspondiente prueba aplicado sobre el k-fold restante.

RESULTADOS Y DISCUSIÓN

Los resultados obtenidos con k-folds se muestran en la tabla 1. La base de datos está constituida por veinte datos. Los datos del 1 al 10 corresponden a hojas de limón persa con síntomas y enfermas de HLB; los objetos del 11 al 20 corresponden a hojas de limón persa sanas. En la Tabla 3 se muestran los resultados al hacerles la prueba a los 5 k-folds. En la primera iteración de entrenamiento se usa el primer fold para validar, los cuatro resultados corresponden a las hojas 1,2,3 y 4 identificadas como enfermas. La primera hoja la evalúa como enferma, porque la salida es $\begin{bmatrix} 0.4223 \\ 0.0636 \end{bmatrix}$, se interpreta como $\begin{bmatrix} 1 \\ 0 \end{bmatrix}$, indicando que la clasifica como enferma. La hoja 2, 3 y 4 también las identifica como enfermas. De tal manera, que tiene 4 aciertos de 4 en ese fold, teniendo una precisión de 100%. Por otra parte, una hoja es identificada como sana cuando el valor inferior es mayor que el valor superior. Por ejemplo, la cuarta hoja del fold 5. Donde la salida es $\begin{bmatrix} 0.3092 \\ 0.5496 \end{bmatrix}$ se interpreta como $\begin{bmatrix} 0 \\ 1 \end{bmatrix}$ que corresponde a la clase de hojas sanas.

Tabla 1
Resultados de validación cruzada K-fold

K-FOLD	HLB	HLB	HLB	HLB	ACIERTOS	EXACTITUD (ACCURACY)
	1	1	1	1	4	1
1	0	0	0	0		
	HLB	HLB	HLB	HLB		
	1	1	0	1	3	0.75
2	0	0	1	0		
	HLB	HLB	SANA	SANA		
	1	1	0	0	4	1

3	0	0	1	1		
	SANA	SANA	SANA	SANA		
	1	1	0	1	1	0.25
4	0	0	1	0		
	SANA	SANA	SANA	SANA		
	0	0	0	0	4	1
5	1	1	1	1		
EXACTITUD GLOBAL						0.8

En la segunda iteración de entrenamiento se usa el segundo fold con una exactitud del 85%. En la tercera iteración se valida con el tercer fold y su exactitud es del 100%. En la cuarta iteración se valida con el cuarto fold con 25% de exactitud. En la quinta iteración correspondiente al fold cinco para validar su exactitud fue de 100%.

Para evaluar el modelo se utilizó la herramienta matriz de confusión, esta es adecuada para medir el rendimiento a modelos de aprendizaje automático supervisado. En la tabla 2 se observa la matriz de confusión del modelo.

Tabla 2
Matriz de confusión de validación cruzada K-fold.

Datos Reales		Enfermedad	
Resultados prueba	HLB	Sanos	Totales
Positivos	9	3	12
Negativos	1	7	8
Total	10	10	20

La exactitud de la prueba se calcula de acuerdo a la siguiente fórmula:

Exactitud= (verdaderos positivos + verdaderos negativos) / (verdaderos positivos + falsos positivos + falsos negativos + verdaderos negativos).

Exactitud = 16 / 20 = 0.8

La sensibilidad representa la capacidad de discriminar los casos positivos de los negativos.

Sensibilidad= verdaderos positivos / (verdaderos positivos + falsos negativos)

Sensibilidad = 9 / 10 = 0.9

La exactitud y sensibilidad son las medidas que interesan saber del modelo, la primera es la cantidad de predicciones positivas que fueron correctas y la segunda es la capacidad de poder detectar correctamente la enfermedad entre las hojas que poseen la enfermedad.

CONCLUSIONES

En el contexto actual, donde los avances tecnológicos y la proliferación de herramientas informáticas están redefiniendo actividades anteriormente reservadas para la intervención humana, la inteligencia artificial emerge como una herramienta crítica en la agricultura, particularmente en la identificación de enfermedades en plantas. Este estudio contribuye a esta área emergente, aplicando técnicas de procesamiento de imágenes y redes neuronales artificiales para detectar la enfermedad de Huanglongbing (HLB) en hojas de limón persa. El uso de técnicas avanzadas como el Análisis de Componentes Principales permitió una reducción del 50% en la dimensionalidad de los datos, facilitando un procesamiento más eficiente.

Como parte de esta investigación, se obtienen varias imágenes de hojas de limón persa enfermas de HLB, de las cuales, sólo diez son aptas para esta investigación. Las imágenes fueron proporcionadas por el comité estatal de sanidad vegetal del estado de Colima. Sin embargo, queda pendiente trabajar para tener una base de datos de imágenes de hojas de limón con HLB para seguir desarrollando soluciones sobre esta línea de investigación.

Se logró reducir la dimensionalidad de los datos en un 50 por ciento, aplicando la técnica de análisis de componentes principales. De 70000 píxeles por imagen se redujeron en 35000 datos correspondientes a los 100 componentes principales.

Con el 80 por ciento de exactitud de este modelo propuesto se concluye que esta propuesta es importante principalmente para pequeños productores debido a que normalmente no son incluidos en las revisiones que realiza el Servicio Nacional de Sanidad, Inocuidad y Calidad Agroalimentaria (SENASICA).

La línea de continuación de este trabajo de investigación es la aplicación de otras técnicas de tratamiento de imágenes digitales; así como, la aplicación de otras técnicas de inteligencia artificial o una combinación de ellas para mejorar la exactitud para identificar enfermedades en los modelos.

También es prioridad, la generación de una base de datos de imágenes de hojas de limón persa con síntomas de la enfermedad HLB. Las imágenes deben estar estandarizadas, ser de calidad y ser lo suficientemente grande con el objetivo de generar mejores resultados.

Esta investigación no solo demuestra la aplicabilidad y eficacia de la inteligencia artificial en el sector agrícola, sino que también sienta las bases para futuras investigaciones que puedan abordar de manera más exhaustiva los desafíos que enfrenta este sector.

REFERENCIAS BIBLIOGRAFICAS

Alemán, J.; Baños, H.; Ravelo, J. 2007. Diaphorina citri y la enfermedad huanglongbing: una combinación destructiva para la producción citrícola. *Revista de Protección Vegetal*, 22(3):154-165.

Berrar, Daniel. (2018). Cross-Validation. 10.1016/B978-0-12-809633-8.20349-X.

Canny, J. (1986). A Computational Approach to Edge Detection. *Transactions on pattern analysis and machine intelligence*, Vol. PAMI-8, No. 6,679-698.

Deng, X.; Li, Z.; Deng, X. and Hong, T. 2014. Citrus disease recognition based on weighted scalable vocabulary tree. *Precision Agriculture*. 15(3):321–330.

FAO. 2014. Gestión Regional del Huanglongbing (HLB) en América Latina y el Caribe. <http://www.fao.org/americas/prioridades/hlb/es/>

Gao, Y.; Lu, Z.; Liu, Z. and Zhong, B. 2013. Research progress on diagnostic methods of citrus Huanglongbing. *J Agric & Biol Eng*. 6(9): 37–40.

González, R. y Woods, R. 1996. Tratamiento digital de imágenes, Addison-Wesley Publishing Co, Reading, Washington. 447-515 pp.

Kumar, A.; Lee, W.; Ehsani, R.; Albrigo, L.; Yang, C. and Mangan, R. 2010. Citrus greening disease detection using airborne multispectral and hyper spectral imaging. In: *Proceeding of the 10th International Conference on Precision Agriculture*. Denver, CO. Paper No. 427. 15. i.e.18– 21pp.

Li, X.; Lee, W.; Li, M.; Ehsani, R.; Mishra, A. and Yang, C. 2011. Comparison of different detection methods for citrus greening disease based on airborne multispectral and hyperspectral imagery. *American Society of Agricultural and Biological Engineers*

Meetin. Doi 10.13031/2013.37734.

Li, X.; Lee, W.; Li, M.; Ehsani, R.; Mishra, A. and Yang, C. 2012. Spectral difference analysis and airborne imaging classification for citrus greening infected trees. *Computers and Electronics in Agriculture*. 83(4):32–46

Li, H.; Lee, W.; Wang, R.; Ehsani, R. and Yang, C. 2014. Spectral angle mapper (SAM) based citrus greening disease detection using airborne hyperspectral imaging. *Precision Agric.* (15):162-183. <https://doi.org/10.1007/s11119-013-9325-6>

Mishra, A.; Karimi, D.; Ehsani, R. and Albrigo, L. 2011. Evaluation of an active optical sensor for detection of Huanglongbing (HLB) disease. *Biosystems Engineering*. 110(3):302-309.

Pourreza, A; Lee W.; Raveh, E.; Ehsani, R. and Etxeberria E. 2014. Citrus Huanglongbing detection using narrow-band imaging and polarized illumination. *Transactions of the ASABE*. 57(1):259–272.

Trujillo-Arriaga, J. 2010. Servicio Nacional de Sanidad, Inocuidad y Calidad Agroalimentaria. Dirección General de Sanidad Vegetal. Oficio B00.01,01,01.03.-14859. Circular No. 056. 02 de diciembre de 2009.

Wang, N.; Pierson, E. A.; Setubal, J. C.; Xu, J.; Levy, J. G.; Zhang, Y. Z. and Martins, J. 2017. The Candidatus Liberibacter-host interface: insights into pathogenesis mechanisms and disease control. *Ann. Rev. Phytopathol.* 107(4):451-482. doi: 10.1146/annurev-phyto-080516-035513.

Zhang, W. 2012. Study on PCR detection of citrus Huanglongbing bacterium. *Biological Disaster Science*. 35(2):164–168.

Zhang, M.; Guo, Y.; Powell, C. H. A.; Doud, M. S.; Yang, C. H. and Duan, Y. 2014. Effective antibiotics against ‘*Candidatus Liberibacter asiaticus*’ in hlb-affected citrus plants identified via the graft-based evaluation. *PLoS ONE*. 9(11):1-11. doi: 10.1371/journal.pone.0111032.